

# HERRAMIENTA DE VISUALIZACIÓN, ANÁLISIS Y CONVERSIÓN DE DATASETS ANALÓGICOS A IMÁGENES PARA SU POSTERIOR PROCESADO POR DEEP LEARNING

**Manuel Rivas Pérez<sup>1</sup>, Francisco Luna-Perejón<sup>1</sup>, Javier Civit-Masot<sup>1</sup>, Lourdes Miró-Amarante<sup>1,2</sup>, Antón Civit<sup>1,2</sup>, Manuel Domínguez-Morales<sup>1,2</sup>**

<sup>1</sup>*Departamento de Arquitectura y Tecnología de Computadores, EPS-ETSII, Sevilla*

<sup>2</sup>*IBUS: Instituto de Ingeniería en Informática, Sevilla*

E-mail de correspondencia: [mrivas@us.es](mailto:mrivas@us.es)

## RESUMEN

Las herramientas de aprendizaje automático se desarrollaron inicialmente para clasificar información visual y detectar patrones en éstas. Debido a ello, muchos trabajos transforman información almacenada analógicamente a imágenes para utilizar sistemas de clasificación basados en redes neuronales convolucionales. Sin embargo, con el auge de las señales fisiológicas se han extendido los sistemas de clasificación que utilizan directamente información analógica en las redes neuronales. Aun así, por experiencia, muchos investigadores continúan transformando la información a imágenes para su procesado. En este trabajo se diseña, desarrolla y prueba una herramienta software capaz de trabajar con un dataset analógico para visualizarlo y almacenarlo en forma de imágenes según las preferencias del usuario y permitiendo diversos procesamientos previos. Esta herramienta permitirá realizar una comparativa exhaustiva entre ambos sistemas de clasificación.

## 1. INTRODUCCIÓN

El Aprendizaje Automático es una rama de la Inteligencia Artificial (IA) que tiene como objetivo principal desarrollar mecanismos que permitan que un computador aprenda (Moreno, 1994). Éste se basa en el análisis de datos y extracción de características de estos, todo realizado de forma automática por un computador. La principal herramienta para extraer esta información y almacenar las características son las redes neuronales artificiales, que consisten en un modelo computacional compuesto por neuronas artificiales conectadas entre sí para transmitirse señales, permitiendo la variación de pesos en estas conexiones y, de esta manera, modificando las señales de entrada hasta obtener la respuesta deseada. Son estos pesos de los enlaces de las neuronas los que modelan la respuesta y contienen el conocimiento aprendido.

Para procesar datos propiamente dichos, se utilizaba inicialmente la estadística inferencial (y actualmente se sigue utilizando en algunos ámbitos), por lo que la necesi-

dad del aprendizaje automático surge cuando los datos a analizar son más complejos y no es trivial extraer características de estos. Es por ello por lo que, inicialmente, estas técnicas se comenzaron a aplicar sobre imágenes.

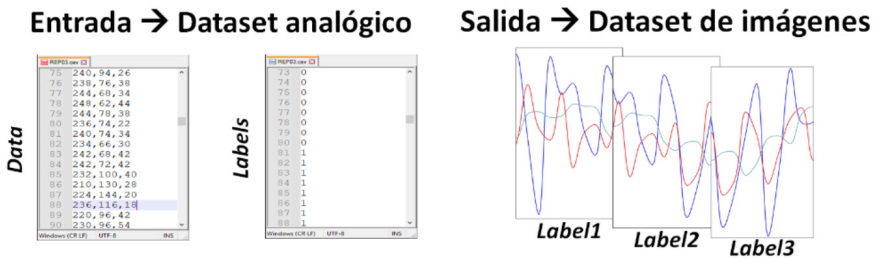
Para ello, se elaboran modelos de redes neuronales convolucionales, que admiten poblaciones bidimensionales de neuronas, activadas independientemente por la información de cada píxel de la imagen. Estas redes neuronales, habitualmente, están formadas por múltiples capas de filtros convolucionales y reducciones de muestreo para ir extrayendo las características buscadas en el modelo (Albawi, 2017). Como resultado, estas redes son ampliamente utilizadas en visión artificial, ya que el procesamiento se asemeja a las neuronas de la corteza visual primaria (V1) de un cerebro biológico. Debido a su uso extendido en la visión artificial, múltiples profesionales del campo de la IA focalizaron su investigación a este ámbito, obteniendo una amplia experiencia al respecto.

Fruto de este hecho, cuando posteriormente se comenzó a dar importancia al procesamiento de señales analógicas (entre ellas, las fisiológicas), estos profesionales adaptaron la información de entrada para poder realizar el procesamiento con los sistemas convolucionales que ya dominaban. Esto implica que estas señales analógicas son transformadas a imágenes para poder ser procesadas por las redes neuronales convolucionales; por supuesto, de una forma totalmente personalizada por parte de cada profesional. Pero surgen redes neuronales y mecanismos especializados en procesar dicho tipo de información analógica con buenos y rápidos resultados.

Por lo tanto, el interés futuro de este trabajo es realizar una comparativa entre las redes neuronales especializadas en señales fisiológicas y las redes neuronales convolucionales que hagan uso de conversiones a imágenes de dichas señales (Chen, 2014). Para ello, en este trabajo se presenta una herramienta software capaz de trabajar con datasets de información almacenada completamente de forma analógica y obtener un conjunto de imágenes que la representen.

## **2. MATERIALES Y MÉTODOS**

Se parte de un conjunto de datasets de prueba, que integran información de tres sensores inerciales con etiquetas, y el resultado es obtener ese mismo dataset particionado en forma de imágenes con un ancho de muestras idéntico y etiquetados automáticamente en base a las señales analógicas de entrada. Puede observarse el objetivo principal de la herramienta en la siguiente figura:



**Figura 1.** Objetivo principal de la herramienta.

**Fuente:** elaboración propia.

Para ello se hará uso de la herramienta Visual Studio, utilizando las librerías de .NET 5, con el fin de permitir la multiplataforma. Además del aspecto visual intuitivo y usable, se precisan las siguientes características para considerarla una herramienta útil para la tarea a desarrollar en el futuro:

- Selección del dataset de entrada: la herramienta debe permitir seleccionar la fuente de entrada, permitiendo la división de la información en varios ficheros si fuera necesario y con las etiquetas en el mismo fichero o en uno diferente.
- Filtrado de la señal: debe permitir aplicar filtros a cada fuente de forma independiente. Inicialmente se incluirán los filtros más comunes, pero puede ser ampliable.
- Visualización con interpolación: debe permitir al usuario que la representación sea fluida e incluya la posibilidad de interpolar los puntos para que el resultado no posea picos.
- Solapamiento: la herramienta debe permitir elegir el porcentaje de solapamiento que tendrán las imágenes resultantes entre ellas.
- Reglas de etiquetado: debido a que el dataset origen posee una etiqueta por muestra y que la herramienta agrupará múltiples muestras en una misma imagen, ésta debe permitir configurar las reglas de etiquetado automático en base al porcentaje de aparición de cada tipo de etiqueta del origen.
- Simulador adaptable: todas las herramientas incluidas se implementarán como módulos, para permitir ampliar con nuevas herramientas y filtros en el futuro.

### 3. RESULTADOS Y DISCUSIÓN

Tras desarrollar la herramienta, se han incluido todos los objetivos propuestos en el apartado anterior, obteniéndose una herramienta útil y, a su vez, visualmente atractiva. El esquema de procesado de la herramienta se muestra a continuación:

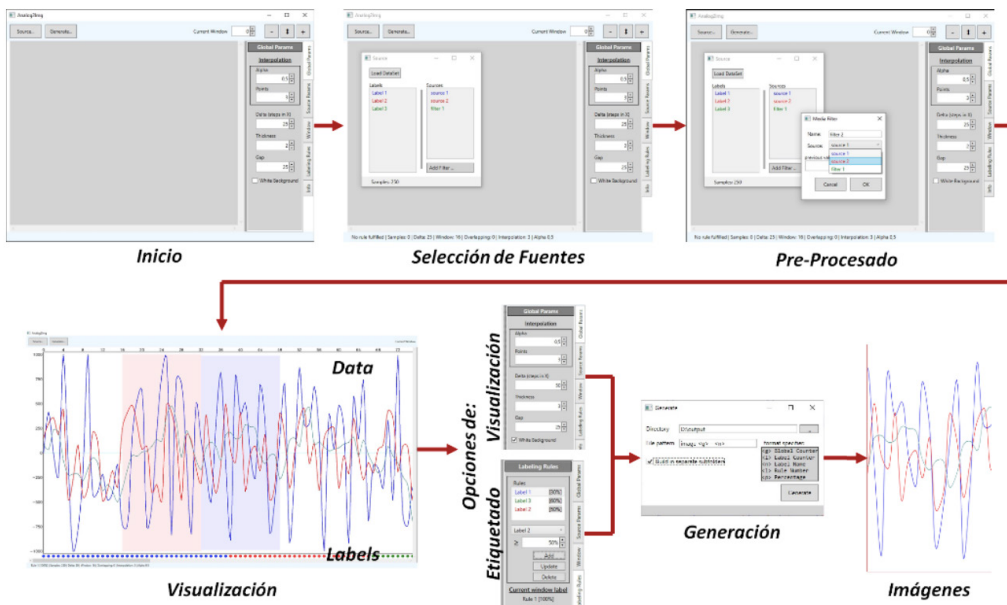


Figura 2. Esquema de procesamiento.

Fuente: elaboración propia.

### 4. CONCLUSIONES

Se ha diseñado, implementado y probado una herramienta software capaz de convertir de forma automática información almacenada analógicamente a información en imágenes. La herramienta permite realizar filtrados de la señal, contiene múltiples opciones de visualización y admite reglas de etiquetado automático para el dataset de salida.

Esta herramienta es muy útil para trabajos futuros de comparativa entre procesamiento por redes neuronales analógicas y redes neuronales convolucionales.

### REFERENCIAS BIBLIOGRÁFICAS

Moreno, A. (1994). Aprendizaje automático.

- Albawi, S., Mohammed, T. A., & Al-Zawi, S.** (2017, August). Understanding of a convolutional neural network. In 2017 International Conference on Engineering and Technology (ICET) (pp. 1-6). Ieee.
- Chen, D. G., Tang, F., Law, M. K., & Bermak, A.** (2014). A 12 pJ/pixel analog-to-information converter based 816× 640 pixel CMOS image sensor. IEEE Journal of Solid-State Circuits, 49(5), 1210-1222.